

Máquinas de Soporte Vectorial para la Detección Automática de la Macroestructura del Sueño

Elvia Palacios, Martín O Mendez
Fac. de Ciencias, UASLP,
Diagonal Sur S/N
Zona Universitaria
S.L.P., México
epalacios@ciencias.uaslp.mx
mmendez@galia.fc.uaslp.mx ,

Anna M Bianchi, Sergio Cerutti
Dep. de Bioingeniería
Politecnico di Milano,
piazza Leonardo da Vinci 32, Italia
nnamaria.bianchi@polimi.it
sergio.cerutti@polimi.it,

Juha M Kortelainen
Machine Vision,
VTT Technical Research Center
of Finland
Tampere, Finland
uha.m.kortelainen@vtt.fi

Resumen— En este trabajo se presenta un algoritmo basado en Máquinas de Soporte Vectorial (SVM) para detectar la macroestructura del sueño (Wake, NREM y REM) a partir de las señales de variabilidad de la frecuencia cardíaca (HRV) y el movimiento. Estas señales son obtenidas de una cama de sensores de presión. Se utilizó el modelo autoregresivo variante en el tiempo (TVAM) como extractor de características de la señal HRV las cuales alimentan a un conjunto de SVM. La información resultante de la polisomnografía y las anotaciones de los expertos de 17 pacientes saludables sirvieron para entrenar y verificar el algoritmo. Se obtuvo una precisión de 86 % y un índice kappa de 0,55. Estos resultados motivan a implementar sistemas automáticos para el monitoreo del sueño fuera de los centros de atención al sueño y para ayudar a los expertos durante los protocolos clínicos.

Palabras clave: Máquinas de soporte vectorial, macroestructura del sueño, variabilidad de la frecuencia cardíaca.

I. INTRODUCCIÓN

Actualmente los médicos han relacionado los desórdenes del sueño (insomnia, apnea, etc.) con muchas enfermedades tales como patologías cardiovasculares, desórdenes psicológicos y/o psiquiátricos, etc. (Rechtschaffen y Kales, 1968) (White, 2006) (Young y Peppard, 2002) (ATLAS, 1996). Estas son las razones por las cuales en Europa y en USA se realizan evaluaciones de la calidad del sueño en Clínicas especiales del Sueño. La evaluación de la calidad de sueño es una práctica poco común en México ya que existen pocas clínicas del sueño. La baja calidad del sueño afecta las capacidades básicas mentales (memoria, aprendizaje y concentración), así como la personalidad, humor y el comportamiento (irritabilidad y somnolencia). También puede acarrear problemas sociales tales como una capacidad de trabajo reducida o un incremento de riesgo de accidentes debido a la baja concentración. Si la condición de una baja calidad del sueño perdura por un largo período, algunas patologías cardiovasculares son frecuentemente asociadas a este hecho, tales como la hipertensión y la insuficiencia cardíaca (ATLAS, 1996).

La calidad del sueño se evalúa a través de un procedimiento estandar llamado polisomnografía (PSG) (Rechtschaffen y Kales, 1968). La PSG consiste en registrar durante toda la noche al menos las tres siguientes señales:

electroencefalografía, electromiografía y electrooculografía. Estas señales son analizadas por médicos expertos en el área, los cuales proporcionan una evaluación de la calidad del sueño (Rechtschaffen y Kales, 1968) y/o los desórdenes del sueño (ATLAS, 1996). La PSG es un procedimiento preciso y se necesita de un largo entrenamiento para ser un experto. Además, la evaluación de un registro de PSG es una tarea que consume tiempo y requiere de equipo especializado junto con una infraestructura específica para la adquisición de las señales. Para evitar estos problemas, actualmente se trabaja en la evaluación de sueño de forma automática basándose en el análisis de señales de fácil adquisición todo esto para obtener características que reproduzcan la evaluación clínica. Solamente unos pocos estudios existen en la literatura: (Watanabe y Watanabe, 2004) (Redmond y Chazal, 2007) (Mendez y Mattucci,) (Kortelainen y Mendez, 2010) donde se presentan algunos resultados confiables. El promedio de las diferentes evaluaciones realizadas por expertos es alrededor del 76 % (Norman y Pal, 2000) lo cual hace difícil establecer un estandar. Estos métodos utilizan la PSG o cualquier otra señal de simple adquisición (electrocardiograma) para desarrollar sistemas automáticos para el sueño. La idea principal de un sistema automático es ayudar a los médicos durante el diagnóstico de la calidad del sueño y disminuir la sobre-estimación de las patologías del sueño, la cual es una consecuencia de la poca accesibilidad del diagnóstico del sueño al público en general (ATLAS, 1996).

A pesar de que las señales básicas de la PSG contienen información importante acerca del proceso del sueño, algunos estudios han demostrado que las señales fisiológicas, tal como la variabilidad de la frecuencia cardíaca (HRV) y la respiración presentan dinámicas acopladas a la macroestructura del sueño (Rápido movimiento de ojos -REM- y No rápido movimiento de ojos -NREM-) y la microestructura del sueño (Mendez y Mattucci,) (Mendez y Bianchi, 2008) (Bonnet y Arand, 1997).

Una ventaja primordial de la señal HRV es que puede ser obtenida a través de técnicas no obstructivas tal como una cama de sensores de presión (no es necesario

colocar sensores en el cuerpo del paciente) (Kortelainen y Mendez, 2010). De las señales registradas por la cama de sensores se obtiene el balistocardiograma (BCG), y la señal HRV se determina basándose en el intervalo del latido del corazón (HBI). Sin embargo, aunque la señal HRV obtenida a través de la cama de sensores tiene información acoplada con la macroestructura, la clasificación automática es difícil ya que los estados del sueño no son linealmente separables en el espacio de características (Watanabe y Watanabe, 2004) (Redmond y Chazal, 2007) (Mendez y Mattucci,) (Kortelainen y Mendez, 2010). Estos trabajos utilizaron las señales de HRV, movimiento y ECG para separar los diferentes estados del sueño y obtuvieron una clasificación aceptable.

Las redes neuronales (NN) y las máquinas de soporte vectorial (SVM) fueron introducidas para lidiar con problemas de clasificación no lineal. (Vapnik, 1998) (Steinwart y Christmann, 2008). Las SVM pueden ser utilizadas como un algoritmo de machine learning (ML) en diferentes aplicaciones, tales como detección de objetos y categorización de textos (Vapnik, 1998) (Steinwart y Christmann, 2008). En el método de las SMV, los datos son mapeados a un espacio de mas alta dimension y entonces se construye el hiperplano separador óptimo de este mapeo no lineal. La solución óptima es modelada con una suma ponderada de los datos (teorema de Mercer) y determinada por un problema de optimización cuadrática. Los datos con pesos diferentes de cero son llamados vectores de soporte, donde los parámetros de la función Kernel son seleccionados de acuerdo a una cota en la minimización del error de generalización (Vapnik, 1998).

El objetivo de este trabajo es proponer un sistema de soporte para evaluar la macroestructura del sueño utilizando la señal HRV obtenida de forma no invasiva con la cama de sensores. La clasificación multi-clase se realiza utilizando el método conocido como uno-contra-uno en SVM bi-clases.

II. MATERIALES Y MÉTODOS

II-A. Protocolo

Este estudio consta de los registros de 11 pacientes femeninas de 20 a 54 años de edad con trabajos donde cambian de turno. Los registros se realizaron en el laboratorio del sueño del Instituto de Salud Ocupacional de Finlandia. Cada paciente participó en 2 registros, uno después de trabajar toda la noche y dormir en el día y otro después de un cambio de turno, es decir, trabajando en el día y una noche normal. Los médicos expertos realizaron un hipnograma de los datos polisomnograficos obtenidos por el procediemiendo estandar (Rechtschaffen y Kales, 1968). El BCG multi-canal fue obtenido a través de una cama de sensores (sensores de presión colocados en un colchón) de donde se extrajo la HRV. Este tipo de sensor fue propuesto por Kortelainen en (Kortelainen y Mendez, 2010). De los 22 registros que se obtuvieron, solo 17 de ellos fueron seleccionados para la extracción de características debido

a que la mayoría de los datos era ruido o por estar fuera de los valores fisiológicos normales.

II-B. Modelo Autoregresivo Variante en el Tiempo (TVAM) y Extracción de Características

El modelo autoregresivo variante en el tiempo (TVAM) es utilizado para analizar series de tiempo no estacionarias (Bianchi y Mainardi, 1993) (Marple, 1987). Este método permite la extracción del contenido frecuencial en una señal. En este trabajo se analiza la señal HRV (x). Sea n el n -ésimo latido y x un vector fila $x = [x(1), x(2) \dots, x(N)]$, donde N es el número total de latidos. Un latido se puede aproximar en un instante n por la siguiente ecuación lineal

$$\tilde{x}(n) = - \sum_{p=1}^P a_p x(n-p), \quad (1)$$

donde a_p son los coeficientes de la ecuación lineal, P el número de coeficientes y $\tilde{x}(n)$ denota el latido estimado. Entonces, el error de estimacion se obtiene por

$$e(n) = x(n) + \tilde{x}(n) = x(n) - \sum_{p=1}^P a_p x(n-p). \quad (2)$$

Cada instante de tiempo, el sistema se mueve hacia un nuevo latido $x(n+1)$, el valor del vector \mathbf{a} de coeficientes es actualizado de forma recursiva por la siguiente ecuación

$$\mathbf{a}(n+1) = \mathbf{a}(n) + \mathbf{k}(n)e(n), \quad (3)$$

donde $\mathbf{k}(n)$ es análoga a la ganancia de Kalman, la cual es actualizada latido-a-latido utilizando un algoritmo de mínimos cuadrados recursivos (Bianchi y Mainardi, 1993) (Marple, 1987). Finalmente, el espectro variante en el tiempo de HRV se obtiene en una base de latido-a-latido de los parámetros (Mendez y Mattucci,) (Bianchi y Mainardi, 1993) mediante

$$\mathbf{s}(f, n) = \left| \frac{\alpha(n)^2 T}{A(z, n)A(z^{-1}, n)} \right|_{2j f \pi}, \quad (4)$$

donde T es el intervalo de muestreo, $\alpha(n)^2$ es la varianza del vector de estimación en el instante n y $A(z, N)$ se calcula por

$$A(z, n) = 1 + \sum_{p=1}^P a_p(n)z^{-p}. \quad (5)$$

El número de coeficientes del modelo lineal que se eligió es 8, ya que lo recomiendan en (Mendez y Mattucci,). Las características latido-a-latido obtenidas del espectro variante en el tiempo de HRV son:

- Potencia total (Total power) - TP (0.003 Hz - 0.5 Hz)
- Potencia a muy baja frecuencia (Very low frequency power) - VLF (0.003 Hz - 0.02 Hz)
- Potencia a baja frecuencia (Low frequency power) - LF (0.02 Hz - 0.15 Hz)
- Potencia a alta frecuencia (High frequency power) - HF (0.15 Hz - 0.5 Hz)

- Modeulo del polo de HF
- Fase del polo de HF

donde las características VLF, LF y HF fueron normalizadas con respecto al TP de cada latido. Después, todas las características fueron transformadas a una resolución de época-a-época (época = 30 seg) la cual es la resolución del hipnograma. El valor de la característica correspondiente a 30 seg es una época, en la fig. 1 se muestra un segmento de noche en el primer ciclo de sueño.

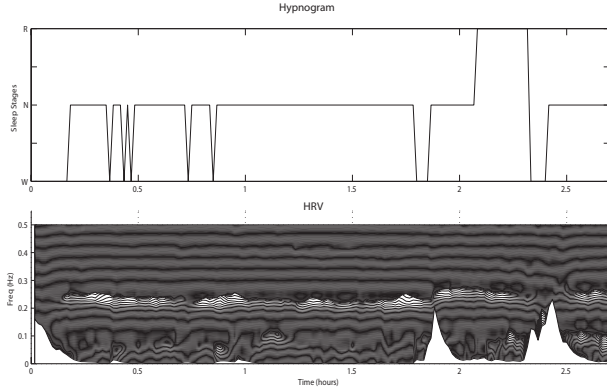


Figura 1. Hipnograma y densidad espectral de potencia de HRV.

II-C. Máquinas de Soporte Vectorial y Clasificación

Una máquina de soporte vectorial es un método de aprendizaje de funciones separatrices aplicado en este trabajo a tareas de clasificación. En las situaciones donde los datos o las clases son linealmente separables, las SVM utilizan un hiperplano separador lineal para crear un clasificador con margen máximo resolviendo un problema de optimización no lineal con restricciones. Si las clases no son linealmente separables, las SVM no lineales transforman el espacio de entrada original en un espacio de características de más alta dimensión a través de varios mapeos no lineales. Por ejemplo, polinomial, sigmoidal y de función de base radial (RBF). Las SVM encuentran el hiperplano separador óptimo en este espacio de características.

Formulación Matemática. Un clasificador con SVM es construido a partir de un conjunto de entrenamiento con l ejemplos etiquetados (\mathbf{x}_i, y_i) , donde $\mathbf{x}_i \in \mathcal{R}^n$ es i -ésimo ejemplo y $y_i \in \{-1, +1\}$ es el valor de la etiqueta de la clase (problema binario).

En el problema de separación de dos clases, el objetivo es encontrar un hiperplano separador óptimo (OSH), el cual se obtiene minimizando una cota superior del error de generalización. En otras palabras, maximizando la distancia más pequeña entre los puntos de cada lado del hiperplano separador (maximizando el margen de separación). Los puntos de entrenamiento más cercanos al OSH son llamados vectores de soporte. Las SVM se basan en la idea de minimizar el riesgo estructural introducido por la teoría del aprendizaje estadístico (Vapnik, 1998)-(Steinwart y Christmann, 2008).

Para resolver el problema de separar el conjunto de vectores de entrenamiento los cuales pertenecen a dos clases diferentes, $D = \{(\mathbf{x}_i, y_i), i = 1, 2, \dots, l\}$, donde l es el número de ejemplos del conjunto de entrenamiento se utiliza un mapeo no lineal $\phi: \mathcal{R}^n \rightarrow F$. Esto es, los datos del conjunto de entrenamiento en el espacio de entrada \mathcal{R}^n son mapeados a un espacio de características euclidiano de dimension más grande $F = \{z \in \mathcal{R}^m | z = \phi(x) \quad \forall x \in \mathcal{R}^n\}$ ($m > n$). Las SVM no lineales construyen un hiperplano en el espacio transformado F definido por

$$d(w, z) = \langle w, z \rangle + b = 0, \quad (6)$$

así, para separar los ejemplos en dos clases se tienen que satisfacer las siguientes condiciones:

$$y_i[\langle w, z_i \rangle + b] \geq 1, \quad \forall i. \quad (7)$$

donde $w \in \mathcal{R}^m$ es el vector de pesos y b es el bias. Para maximizar el margen de separación $2/\|w\|$ el hiperplano que separa de forma óptima las dos clases debe ser determinado. Esto es, hay que resolver el siguiente problema de optimización cuadrática convexa

$$\min \frac{1}{2} \|w\|^2, \quad (8)$$

bajo las restricciones de la ecuación 7. Este margen se puede considerar como una medida de la propiedad de generalización de las SVM. Entre más grande sea el margen, mejor sera la generalización. Entonces, para encontrar el hiperplano óptimo definido por (w, b) , el problema de optimización (8) se convierte a su problema dual construyendo el Lagrangiano $\mathcal{L}(\alpha)$ e introduciendo los multiplicadores no negativos α_i , resultando en el siguiente problema de programación cuadrática (QP)

$$\begin{aligned} \max_{\alpha} \mathcal{L}(\alpha) &= \max_{\alpha} \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j \langle z_i, z_j \rangle, \quad (9) \\ \text{s.t.} \quad \sum_{i=1}^l \alpha_i y_i &= 0, \quad 0 \leq \alpha_i \leq C, \text{ for } i = 1, \dots, l. \end{aligned}$$

donde C es un parámetro constante y positivo utilizado para establecer un compromiso entre el margen máximo y el error de entrenamiento mínimo. En este trabajo se utilizó una $C = \infty$ obtenida por los experimentos. Note que esta función objetivo depende solamente de un conjunto de multiplicadores de Lagrange $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_l)$. Los vectores de soporte son estas α s cercanas al hiperplano que tienen $\alpha_i > 0$. Entonces, resolviendo el problema (9), el hiperplano óptimo con margen máximo es

$$d(x) = \sum_{i=1}^l \alpha_i^* y_i \langle z, z_i \rangle + b^* = 0. \quad (10)$$

Introduciendo el kernel $K(x, x_i) = \langle z, z_i \rangle$, el hiperplano óptimo puede reescribirse como

$$d(x, \alpha^*, b^*) = \sum_{i=1}^l \alpha_i^* y_i K(x, x_i) + b^* = 0. \quad (11)$$

donde la función de mapeo actual, ϕ , no necesita conocerse. Entonces, para un nuevo patrón de entrada x , la regla de decisión para el problema de clasificación es

$$i_f(x) = \text{sign}(\langle w, z \rangle + b^*), \quad (12)$$

$$= \text{sign} \left[\sum_{i=1}^l \alpha_i^* y_i K(x, x_i) + b^* \right]. \quad (13)$$

El problema de programación cuadrática (QP) en la eq. 9 se resuelve para obtener los multiplicadores de Lagrange α para cada SVM. La función kernel utilizada en este trabajo es la RBF (Steinwart y Christmann, 2008):

$$K(x_i, x_j) = \exp \left(-\frac{\|x_i - x_j\|^2}{2\sigma^2} \right) \quad \text{with } \sigma = 1, 2, \dots, 10, \quad (14)$$

donde $\langle \cdot, \cdot \rangle$ denota el producto interno y $\| \cdot \|$ es la norma Euclidiana.

El método uno-contra-uno fue utilizado para la tarea de multi-clasificación. Las SVMs son construidas para todos los pares posibles de clases $N(N-1)/2$ funciones de decisión, donde N es el número de clases. Como hay 3 clases (Wake, REM y NREM), se necesitan 3 SVMs para separar los siguientes pares de clases: REM-NREM, REM-Wake y NREM-Wake. Para este propósito se define la siguiente función

$$d_{ij}(\mathbf{x}) = \langle w_{ij}, \phi(x) \rangle + b_{ij}, \quad (15)$$

esta es la función de decisión que separa la i -ésima clase de la j -ésima clase. Si el nuevo patrón de entrada \mathbf{x} pertenece a la i -ésima región

$$R_i = \{ \mathbf{x} | \text{sign}(d_{ij}) = +1, j = 1, \dots, n; j \neq i \}, \quad (16)$$

entonces se dice que \mathbf{x} pertenece a la clase i . Si \mathbf{x} no pertenece a R_i para $i = 1, \dots, n$, es posible obtener una clasificación utilizando un esquema de selección de votos definido de la siguiente manera

$$d_i(\mathbf{x}) = \sum_{j=1, j \neq i}^n \text{sign}(d_{ij}(\mathbf{x})), \quad (17)$$

esto proporciona el número de veces que \mathbf{x} fue asignado a la i -ésima clase. Así, la siguiente función de decisión se considera

$$d(x) = \arg \max_{i=1, \dots, n} d_i(x). \quad (18)$$

Esto es, si el valor de $d(x)$ es máximo para un valor dado de i , se dice que x pertenece a i -ésima clase. El mayor número de votos que un ejemplo \mathbf{x} puede tener es $N-1$, entonces, si $x \in R_i$, $d_i(x) = N-1$ y $d_k(x) < N-1$ para $k \neq i$.

II-D. Proceso de Entrenamiento

Se utilizó el procedimiento de validación cruzada para entrenar y verificar el algoritmo de clasificación propuesto (Duda y Hart, 2001). Para entrenar las 3 SVM's (NREM-REM, REM-WAKE y WAKE-NREM), se tomaron 4000

datos de forma aleatoria, los cuales equivalen al 31% del total de los datos. Después, los datos de cada paciente fueron considerados para verificar el algoritmo. Se obtuvieron la precisión, y el índice kappa entre otros parámetros. Los experimentos de entrenamiento y verificación para las 3 SVM se realizaron 10 veces con diferentes datos de entrenamiento. El valor $\sigma = 0,05$ para el Kernel se eligió por inspección.

El proceso de diseño total se describe a continuación: Primero, se resuelve el problema QP para obtener los multiplicadores de Lagrange α para cada SVM utilizando la función kernel. Después, cada SVM fue verificada con los datos de los 17 pacientes y las salidas de las 3 SVM entraron al esquema de selección de votos para obtener una clasificación final.

II-E. Desempeño e Indices Clínicos

La salida del algoritmo de clasificación propuesto nos proporciona el perfil del sueño con las clases Wake, NREM y REM de cada registro. El perfil de sueño de cada registro se comparó con su respectivo hipnograma usando los índices estadísticos como precisión, índice Cohen Kappa, etc. Los índices que se calcularon fueron: eficiencia del sueño (tiempo total en REM y NREM dividido por el tiempo total en cama-TC), porcentaje de Wake (Wake/TC), REM (REM/TC) y NREM (NREM/TC).

III. RESULTADOS

En la tabla I se presentan los índices de desempeño que se calcularon para cada paciente. De acuerdo a estos índices la concordancia entre el hipnograma y el perfil del sueño calculado es buena, en la mayoría de los registros, el promedio del índice kappa es mayor que 0.55 y la precisión promedio es mayor que el 86%. Entonces, como se esperaba, los valores de los índices de desempeño calculados son muy cercanos a los valores de los hipnogramas.

En las figuras 2 y 3 se muestran los hipnogramas y perfiles de sueño para la mejor y la peor clasificación que se obtuvieron, respectivamente.

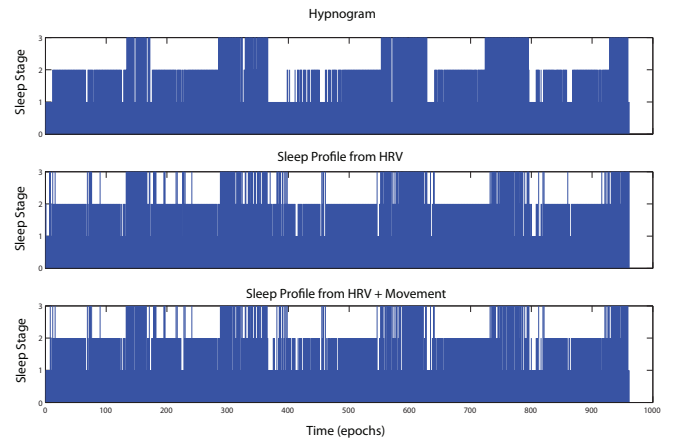


Figura 2. Mejor clasificación obtenida.

TABLA I

DESEMPEÑO DEL SISTEMA AUTOMÁTICO PARA DETECTAR LA MACRO ESTRUCTURA DEL SUEÑO A PARTIR DE LA VARIABILIDAD DE LA FRECUENCIA CARDÍACA EXTRAIDA DE UNA CAMA DE SENSORES

Paciente	Pre	Kappa	ESm	ESa	Wake/TBm	Wake/TBa	REM/TBm	REM/TBa	NREM/TBm	NREM/TBa
1-d	0.87	0.56	0.93	0.96	0.07	0.04	0.25	0.25	0.69	0.70
2-n	0.86	0.61	0.84	0.93	0.16	0.07	0.30	0.30	0.55	0.63
3-d	0.80	0.46	0.71	0.88	0.29	0.11	0.15	0.18	0.56	0.71
4-n	0.84	0.58	0.80	0.92	0.20	0.08	0.27	0.27	0.53	0.65
5-d	0.77	0.36	0.74	0.93	0.26	0.07	0.14	0.26	0.59	0.67
6-n	0.81	0.45	0.87	0.95	0.13	0.05	0.29	0.24	0.58	0.71
7-d	0.85	0.34	0.81	0.97	0.19	0.03	0.08	0.08	0.73	0.89
8-n	0.84	0.43	0.86	0.97	0.14	0.03	0.18	0.17	0.68	0.80
9-d	0.87	0.51	0.88	0.96	0.12	0.04	0.18	0.17	0.71	0.79
10-n	0.88	0.58	0.92	0.95	0.08	0.05	0.22	0.21	0.70	0.74
11-d	0.88	0.51	0.93	0.97	0.07	0.03	0.20	0.15	0.73	0.82
12-n	0.87	0.52	0.92	0.95	0.08	0.05	0.19	0.19	0.73	0.76
13-d	0.88	0.51	0.92	0.97	0.08	0.03	0.19	0.17	0.74	0.80
14-n	0.86	0.55	0.88	0.96	0.12	0.04	0.25	0.22	0.64	0.74
15-d	0.79	0.35	0.72	0.92	0.28	0.08	0.10	0.13	0.62	0.79
16-n	0.86	0.52	0.88	0.96	0.12	0.04	0.23	0.21	0.66	0.75
17-n	0.80	0.44	0.75	0.95	0.25	0.05	0.18	0.22	0.57	0.73
mean	0.84	0.48	0.84	0.95	0.14	0.05	0.19	0.19	0.64	0.74
mean-d	0.83	0.44	0.82	0.94	0.14	0.04	0.15	0.16	0.66	0.76
mean-n	0.84	0.51	0.85	0.94	0.13	0.04	0.22	0.22	0.62	0.72

Acc, = precisión, Kappa = Índice Kappa , ES = eficiencia del sueño, TC = Tiempo en la cama, a = svm, m = hipnograma, -d=día y -n=noche

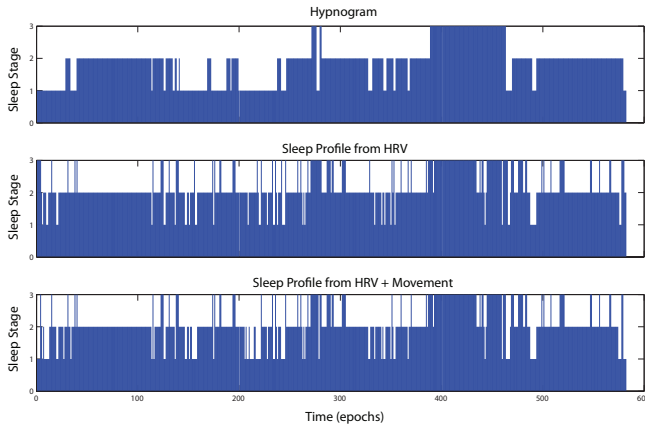


Figura 3. Peor clasificacion obtenida.

IV. CONCLUSIONES

Basándose en los índices de desempeño el algoritmo propuesto parece tener una buena concordancia con el hipnograma. Este algoritmo se basa en señales de fácil adquisición. Los resultados presentados son estables y ofrecen un sistema alternativo para monitorear la calidad del sueño dentro o fuera de las clínicas del sueño. Este algoritmo puede ayudar a los médicos para ahorrar tiempo para una evaluación de la calidad del sueño. Por otro lado, los resultados demostraron que con solo la señal HRV se pueden extraer características que reflejen la calidad del sueño, además de que las SVM demostraron su gran capacidad de generalización en un problema tan complejo como la clasificación de la macroestructura del sueño.

V. AGRADECIMIENTOS

Este trabajo fue apoyado por SEP-Conacyt (61375).

REFERENCIAS

Rechtschaffen, A. y A.E. Kales (1968). A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects.? *U.S. Government Printing Office*, NIH Publication No. 204, Washington, DC.

White D. P. (2006). Sleep Apnea. *Proc. Am. thorac. Soc.* **3**, 124–128.

Young, T., P. E. Peppard y D. G. Gottler (2002). Epidemiology of obstructive sleep ppnea, a population health perspective. *Am. J. Respir. Crit. Care. Med.* **165**, 1217–1239.

port of American Academy of sleep Medicine Task Force, “Sleep-related breathing disorders in adults: recommendations for syndrome definition and measurement techniques in clinical research”, *Sleep*, vol. 22 no. 5, pp. 667-689, Aug. 1999.

Watanabe, T. y K. Watanabe (2004). Noncontact method for sleep stage estimation ”Biomedical Engineering. *IEEE Trans. Biomed. Eng.*, **51–10**, 1735–1748.

Redmond, S.J., P. De Chazal, C. OBrien, S. Ryan, T.W. McNicholas, y C. Heneghan (2007). Sleep staging using cardiorespiratory signals. *Somnologie* **11**, 245–256.

Mendez, M.O., M. Matteucci, V. Castronovo, L. Ferini-Strambi, S. Cerutti y A.M. Bianchi (2009). Sleep staging from Heart Rate Variability: time-varying spectral features and Hidden Markov Models. *IJBET*, in press.

Kortelainen, J.M., M.O. Mendez, M. Matteucci, S. Cerutti, A.M. Bianchi, Sleep Staging based on Signals Acquired through Bed Sensor (2010). *IEEE-TITB*, **14-3**, 776–785.

Norman, R.G., I. Pal, C. Stewart, J.A. Walsleben, D.M. Rapoport (2000). Interobserver agreement among sleep scorers from different centers in a large dataset. *Sleep* **23-7**, 901–908.

Vapnik, V. *Statistical learning theory*. John Wiley & Sons.

Steinwart, I. y A. Christmann (2008). *Support Vector Machines*. Springer-Verlang.

Mendez, M.O., A.M. Bianchi, N. Montano, V. Patrino, E. Gil, C. Mantaras, S. Aiolfi y S. Cerutti (2008). On arousal from sleep: time-frequency analysis. *Medical and Biology Engineering and Computing* **46-4**, 341–351.

Bonnet, M.H. y D.L. Arand (1997). Heart rate variability: sleep stage, time of night, and arousal influences. *Electroencephalogr. Clin. Neurophysiol.* **102-5**, 390–396.

- Scholz, U.J., A.M. Bianchi, S. Cerutti, y S. Kubicki (1997). Vegetative background of sleep: Spectral analysis of the heart rate variability. *Physiol. Behav.* **62-5**, 1037–1043.
- Task force of the European Society of Cardiology and the North American Society of Pacing and Electrophysiology (1996). Heart rate variability: Standards of Measurement, physiological interpretation, and Clinical Use. *Circulation* **93**, 1043–1065.
- Bianchi, A.M., L.T. Mainardi, E. Petrucci, M.G. Signorini, S. Cerutti (1993). Time-variant power spectrum analysis for the detection of transient episodes in HVR signal. *IEEE Trans. Biomed. Eng.* **40**, 136–144.
- Marple, S. *Digital spectral analysis with applications*, Prentice-Hall.
- Sadeh, A., K.M. Sharkey y M.A. Carskadon (1994). Activity-Based Sleep-Wake Identification: An empirical Test of Methodological Issues. *Sleep*, **17**, 201–207.
- Duda, R.O., P.E. Hart y D.G. Stork (2001). *Pattern classification*, Wiley.